

ANALISIS PERFORMA ARSITEKTUR ALEXNET DAN VGG16 PADA DATASET PRIMER CITRA LAPANGAN UNTUK DETEKSI KERUSAKAN PANEL SURYA

Ninuk Wiliani¹, Agung Saputra², Iman Paryudi²

^{1,2,3}Universitas Pancasila, Jakarta

Email: ¹ninuk.wiliani@univpancasila.ac.id, ¹agung@univpancasila.ac.id,
¹iman.paryudi@univpancasila.ac.id,

Submit: 10 Juni 2026, Diterima: 12 Juli 2026, Diterbitkan: 30 Juli 2026

Abstrak: Panel surya (photovoltaic) rentan mengalami penurunan efisiensi akibat kerusakan fisik permukaan seperti retak (crack) dan goresan (scratch). Penggunaan Deep Learning seperti AlexNet dan VGG16 merupakan pendekatan umum dalam visi komputer, namun evaluasinya pada kondisi citra lapangan (field condition) yang memiliki variasi pencahayaan dan latar belakang kompleks masih terbatas. Penelitian ini bertujuan untuk menguji dan membandingkan performa arsitektur AlexNet dan VGG16 dalam mengklasifikasikan kerusakan panel surya. Keterbaruan (novelty) penelitian ini bertumpu pada penggunaan dataset primer sebanyak 1.000 citra riil lapangan (500 crack dan 500 scratch) yang dilatih dari awal (training from scratch), serta penekanan evaluasi pada kapasitas pemisahan batas kelas (class separability) berbasis Area Under Curve (AUC) dan analisis kedalaman lapisan konvolusi. Kedua model dilatih menggunakan optimasi Adam (learning rate 0,001, batch size 16) dengan mekanisme Early Stopping. Hasil eksperimen menunjukkan bahwa meskipun AlexNet dan VGG16 memperoleh akurasi yang relatif berdekatan yaitu sebesar 88,93% dan 89,57% (selisih 0,64%), VGG16 menunjukkan keunggulan yang jauh lebih signifikan pada skor AUC yaitu 0,90 (Excellent Classification) dibandingkan AlexNet yang hanya sebesar 0,68 (Poor Classification). Kedalaman 13 convolutional layer berfilter kecil (3x3) pada VGG16 terbukti lebih presisi dalam mengekstrak fitur garis halus retakan tanpa terpengaruh noise lapangan dibandingkan filter besar pada AlexNet.

Kata kunci: Solar Panel, Convolutional Neural Network, AlexNet, VGG16, dataset primer lapangan, area under curve

Abstract: Solar photovoltaic (PV) panels are susceptible to efficiency degradation due to physical surface defects such as cracks and scratches. While Deep Learning architectures like AlexNet and VGG16 are widely used in computer vision, their evaluation on real-world field-acquired images with varying illumination and complex backgrounds remains limited. This study aims to evaluate and compare the performance of AlexNet and VGG16 in classifying PV module surface defects. The primary novelty of this work lies in the utilization of a primary field dataset comprising 1,000 real-world images (500 cracks and 500 scratches) trained from scratch, combined with an in-depth analysis of class separability using Area Under the ROC Curve (AUC) and layer depth sensitivity. Both models were trained using the Adam optimizer (learning rate 0.001, batch size 16) integrated with an Early Stopping callback. Experimental results reveal that while AlexNet and VGG16 achieved closely matching accuracies of 88.93% and 89.57% respectively (a 0.64% margin), VGG16 demonstrated a far superior AUC score of 0.90 (Excellent Classification) compared to AlexNet's 0.68 (Poor Classification). The 13 small-filter (3x3) convolutional layers in VGG16 proved more capable of capturing subtle linear crack features under field noise than AlexNet's larger receptive fields.

Keywords: Solar Panel, Convolutional Neural Network, AlexNet, VGG16, primary field dataset, area under curve

1. PENDAHULUAN (huruf besar, 10pt, tebal)

Peningkatan jumlah penduduk menyebabkan konsumsi bahan bakar fosil semakin tinggi, sementara ketersediaannya kian menipis[1]. Penggunaan energi terbarukan, khususnya energi matahari melalui teknologi sel surya (photovoltaic / PV), menjadi solusi utama untuk menghasilkan energi listrik yang ramah lingkungan. Namun, efisiensi keluaran daya modul PV sangat dipengaruhi oleh kondisi fisik permukaan panel[2].

Masalah utama yang sering dihadapi adalah timbulnya cacat fisik seperti retakan mikroskopis (*crack*) akibat tekanan mekanis serta goresan (*scratch*) akibat paparan lingkungan atau pembersihan yang tidak

tepat[3]. Cacat fisik ini, apabila tidak dideteksi dan ditangani secara dini, dapat menurunkan efisiensi konversi daya secara signifikan hingga memicu kerusakan permanen pada sistem panel surya[4].


Identifikasi kerusakan secara manual pada permukaan panel surya tergolong sulit dilakukan secara langsung karena karakteristik visual antara retakan dan goresan memiliki kesamaan bentuk serta dimensi yang relatif kecil[5]. Oleh karena itu, dibutuhkan sistem inspeksi otomatis berbasis visi komputer yang akurat[6].

Berbagai penelitian terdahulu telah menerapkan metode pembelajaran mesin dan komputer visi untuk identifikasi cacat sel surya [7], [8] Namun, sebagian besar studi bergantung pada dataset sekunder terstandarisasi atau citra inframerah termografi yang mahal dan sulit diterapkan pada inspeksi rutin skala kecil [9]. Peneliti terdahulu juga cenderung berfokus pada arsitektur CNN kompleks seperti ResNet atau EfficientNet [10]. Meskipun arsitektur modern tersebut memiliki performa tinggi pada dataset raksasa, model tersebut membutuhkan daya komputasi (*computational overhead*) yang tinggi serta rentan mengalami *overfitting* ketika dilatih pada dataset spesifik yang terbatas di lapangan[11] Di sisi lain, arsitektur dasar seperti AlexNet dan VGG16 menawarkan struktur yang efisien dan ringan untuk diterapkan pada perangkat inspeksi *edge/embedded*[12]. Namun, evaluasi mendalam mengenai batas pemisahan kelas (*class separability*) serta sensitivitas kedalaman layer antara AlexNet dan VGG16 khusus pada dataset primer citra tampak (*visible RGB*) kondisi lapangan masih belum banyak dieksplorasi secara komprehensif. Oleh karena itu, penelitian ini mengisi celah (*research gap*) tersebut dengan menganalisis perbandingan performa kedua arsitektur tersebut menggunakan dataset primer riil lapangan.

Pendekatan *Deep Learning*, khususnya *Convolutional Neural Network* (CNN)[13], telah terbukti sangat efektif dalam tugas klasifikasi dan pengenalan citra. Dalam CNN, pemilihan arsitektur sangat menentukan performa ekstraksi fitur[14]. Penelitian ini menguji dan membandingkan dua arsitektur CNN terkemuka, yaitu AlexNet dan VGG16, untuk mengklasifikasikan jenis kerusakan permukaan panel surya (*crack* dan *scratch*)[15]. Penelitian ini bertujuan untuk menentukan model arsitektur terbaik yang menghasilkan tingkat akurasi dan keandalan tinggi.

2. METODE PENELITIAN

Penelitian ini dilaksanakan mengikuti tahapan kerangka kerja kualitatif dan eksperimental kuantitatif berbasis alur *CRISP-DM*[16]. Tahapan penelitian meliputi *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*.



Gambar 1. Tahapan penelitian

1. Pengumpulan Dataset (*Data Understanding*)

Pada tahap implementasi pemahaman data dibagi menjadi dua folder, yakni folder data training dan validation[17]. Kemudian setelah dibagi kedalam dua folder dataset tersebut dibagi kembali menjadi dua kategori sesuai dengan label yang diinginkan pada model alexnet[18]. Dua kategori tersebut adalah Crack dan Scratch, terdapat pada tabel 1


Tabel 1. *Dataset*

Kelompok data	Crack	Scratch
Training	350	350
Validasi	100	100
Test	50	50
Total	500	500

Dataset yang digunakan merupakan dataset primer berformat RGB yang diambil menggunakan kamera *smartphone* pada modul panel surya. Dataset dikelompokkan ke dalam 2 kelas kerusakan utama, disajikan pada tabel 2

- a. Crack (Retak)[19]: Kerusakan permukaan akibat tekanan mekanis atau beban termal
- b. Scratch (Goresan) [20]: Kerusakan garis akibat sentuhan fisik atau gesekan benda tajam.

Tabel 2. Sampel Gambar

Crack	Scratch
	
500 citra	500 citra

2. Pra-pemrosesan Data (*Data Preparation*)
- Sebelum dilatih ke dalam model, dilakukan serangkaian pra-pemrosesan citra[21]:
- a. Resize Citra: Mengubah dimensi seluruh citra masukan menjadi ukuran standar 227 x 227 piksel agar sesuai dengan spesifikasi input jaringan konvolusi disajikan pada Tabel 3 dengan code berikut :

```
import os
from PIL import Image
import numpy as np
from tensorflow.keras.preprocessing.image import load_img, img_to_array, save_img

# Fungsi untuk mengubah ukuran piksel citra
def resize_image(input_dir, output_dir, target_size):
    if not os.path.exists(output_dir):
        os.makedirs(output_dir)

    for filename in os.listdir(input_dir):
        if filename.endswith('.png') or filename.endswith('.jpg'):
            image_path = os.path.join(input_dir, filename)
            image = load_img(image_path)
            resized_image = image.resize(target_size, Image.ANTIALIAS)

            output_path = os.path.join(output_dir, filename)
            save_img(output_path, resized_image)
            print(f'{filename} berhasil diubah ukuran.')

# Tentukan direktori input dan output, serta ukuran target piksel
input_dir = '/content/drive/MyDrive/Solar_Panel/Data_Akili/Crack'
output_dir = '/content/drive/MyDrive/Solar_Panel/Resize/Crack'
target_size = (227, 227) # Ubah sesuai kebutuhan

# Panggil fungsi resize_image
resize_image(input_dir, output_dir, target_size)
```

Tabel 3. *Resizing* Citra

Gambar Asli	Resizing
Crack  831 × 1224 pixel	Resizing Crack  227×227 pixel
Scratch  1280 × 720 pixel	Resizing Scratch  227×227 pixel

- b. Augmentasi Data: Menerapkan fungsi `ImageDataGenerator()` untuk memperbanyak variasi citra latih guna mencegah kondisi *overfitting*[22]. Dengan code pada tabel 4.

Tabel 4. Hasil dari Augmentasi Data

<pre> train_datagen = ImageDataGenerator(rescale=1./255, shear_range=0.2, horizontal_flip=True, fill_mode='nearest') test_datagen = ImageDataGenerator(rescale=1./255, shear_range=0.2, horizontal_flip=True, fill_mode='nearest') valid_datagen = ImageDataGenerator(rescale=1./255, shear_range=0.2, horizontal_flip=True, fill_mode='nearest') </pre>	• <i>Rescale</i> = 1/255 • <i>Shear_range</i> = 0.2 • <i>Horizontal_flip</i>= True • <i>fill_mode</i>='nearest'
--	--

setelah proses ini dijalankan terdapat hasil:

Found 1400 images belonging to 2 classes.
Found 400 images belonging to 2 classes.

Gambar 2 *Output* Augmentasi


- c. Pembagian Dataset (*Splitting*): Data dibagi menjadi folder data latih (*training*), validasi (*validation*), dan uji (*testing*)[23].

3. Pemodelan Arsitektur (*Modeling*), Penelitian ini membandingkan dua arsitektur CNN


Pada penelitian ini, pelatihan model AlexNet dan VGG16 dilakukan dari awal (training from scratch) tanpa memanfaatkan bobot pretrained (seperti ImageNet). Seluruh bobot awal (initial weights) dieksekusi secara acak dan diperbarui secara menyeluruh (full fine-tuning) melalui mekanisme backpropagation menggunakan dataset citra kerusakan panel surya yang dikumpulkan

Rincian arsitektur yang digunakan adalah sebagai berikut

- a. Arsitektur AlexNet [18]: Terdiri dari 5 lapisan konvolusi (convolutional layers) dengan kombinasi ReLU dan Max-Pooling untuk ekstraksi fitur spasial, diikuti oleh 3 Fully Connected (FC) layer. Pada FC layer terakhir, jumlah neuron disesuaikan menjadi 2 output sesuai dengan kelas target (crack dan scratch) dengan aktivasi Softmax seperti pada gambar 3.



Gambar 3. Tahapan Alexnet




Gambar 4. Tahapan VGG16

- b. Arsitektur VGG16 [24]: Terdiri dari 13 lapisan konvolusi dengan ukuran kernel 3×3 , 5 lapisan *Max-Pooling*, serta lapisan *Dropout* (0.5) pada *FC layer* untuk mencegah *overfitting*. Lapisan *output* akhir disesuaikan menjadi 2 neuron dengan aktivasi *Softmax*[25] seperti gambar 4.

Kedua model dikompilasi menggunakan optimizer Adam dengan *learning rate* sebesar 0.001, fungsi kerugian *categorical crossentropy*, *batch size* sebesar 16, dan dikonfigurasi hingga maksimum 100 *epoch*. Untuk mengoptimalkan waktu pelatihan dan menghindari *overfitting*, diterapkan teknik *Early Stopping* dengan parameter *monitor='loss'*, *min_delta=0.01*, dan *patience=3*.

4. Evaluasi Model (*Evaluation*)

Evaluasi performa klasifikasi diukur menggunakan *Confusion Matrix* dengan metrik Akurasi serta pengujian *Area Under the Curve* (AUC)[26] untuk menentukan kualifikasi tingkat performa model. Menggunakan rumus pada gambar 5



Gambar 5. Confusion Matrix

Di mana:

- True Positive (TP) : Citra kerusakan terdeteksi sesuai dengan kelas aslinya.
- False Positive (FP) : Citra dari kelas lain yang salah terprediksi ke kelas target.
- False Negative (FN) : Citra dari kelas target yang terprediksi sebagai kelas lain.

3. HASIL DAN PEMBAHASAN

Pada tahap implementasi pemahaman data dibagi menjadi dua folder, yakni folder data training dan validation. Kemudian setelah dibagi kedalam dua folder dataset tersebut dibagi kembali menjadi dua kategori sesuai dengan label yang diinginkan pada model alexnet. Dua kategori tersebut adalah Crack dan Scratch, terdapat pada tabel 5

Tabel 5. Split dataset

Dataset		
Train	Val	Test
Crack	Crack	Crack
Scratch	Scratch	Scratch


1. Pelatihan Model dan Konvergensi

Proses pelatihan dilakukan pada lingkungan *Google Colaboratory*. Integrasi callback *Early Stopping* terbukti efektif menghentikan iterasi *epoch* secara otomatis ketika penurunan nilai *loss* pada data latih tidak lagi signifikan (di bawah *min_delta = 0.01* selama 3 *epoch* berturut-turut).

Untuk menjaga transparansi dan keterulangannya (*reproducibility*), seluruh konfigurasi perangkat lunak, perangkat keras, dan hyperparameter eksperimen dirangkum pada Tabel 6.

Tabel 6. Hyperparameter Eksperimen

Komponen / Parameter	Spesifikasi / Nilai Konfigurasi
Framework Deep Learning	Python 3.x, TensorFlow 2.x, Keras API
Lingkungan Eksperimen	Google Colaboratory (Cloud-based Environment)
Perangkat Keras (Hardware)	Intel(R) Xeon(R) CPU @ 2.20GHz, NVIDIA Tesla T4 GPU (16 GB VRAM)
Metode Pelatihan	<i>Training from Scratch</i> (Inisialisasi bobot acak)
Optimizer	Adam (<i>Adaptive Moment Estimation</i>)
Learning Rate	0,001
Fungsi Kerugian (Loss)	<i>Categorical Crossentropy</i>
Ukuran Batch (Batch Size)	16
Maksimum Epoch	100 Epoch
Mekanisme Penghentian	<i>Early Stopping</i> (<i>monitor='loss'</i> , <i>min_delta=0.01</i> , <i>patience=3</i>)




Gambar 6. Accuracy pada model AlexNet




Gambar 7. Loss pada model AlexNet

Pada Gambar 6 dan 7 adalah diagram training accuracy dan validation accuracy yang terdapat pada epoch ke 74 menghasilkan akurasi yang tertinggi yaitu 0.8906, epoch dengan nilai terendah saat epoch ke 2 yaitu 0.5260, pada validasi accuracy, pada training accuracy epoch yang tertinggi saat epoch ke 70 yaitu 0.9810, dan epoch dengan nilai terendah saat epoch ke 2 yaitu 0.7756.



Gambar 8 Accuracy pada model VGG16



Gambar 9. Loss pada model VGG16

Pada Gambar 8 dan 9 terdapat training loss dan validasi loss mempunyai hasil loss yang tertinggi dan terendah, yaitu pada saat training loss yang tertinggi saat epoch ke 1 yaitu 0.6693, dan yang terendah saat epoch ke 10 yaitu 0.3010, pada validasi loss yang tertinggi saat epoch ke 1 yaitu 0.6182 dan yang terendah saat epoch ke 10 yaitu 0.3365.

2. Perbandingan Performa Klasifikasi

Setelah proses fitting selesai, kedua model dievaluasi pada dataset pengujian (*testing data*). Pengujian pendeteksian citra dilakukan sebanyak 20 kali percobaan independen pada kedua kelas.

Hasil pengujian dan evaluasi matriks performa disajikan pada Tabel 6

Tabel 6. Hasil Perbandingan Performa Arsitektur AlexNet dan VGG16

Parameter Evaluasi	Arsitektur AlexNet	Arsitektur VGG16
Optimizer / Learning Rate	Adam / 0.001	Adam / 0.001
Deteksi Benar (dari 20 uji)	13 citra	18 citra
Deteksi Salah / Missed	7 citra	2 citra
Akurasi Model (%)	88,93%	89,57%
Nilai AUC	0,68	0,90
Kategori Klasifikasi (AUC)	<i>Poor Classification</i>	<i>Excellent Classification</i>

3. Pembahasan

Berdasarkan hasil pengujian pada Tabel 7:

1. Arsitektur AlexNet memperoleh akurasi sebesar 88,93% dengan nilai AUC 0,68. Dari 20 citra uji yang dievaluasi, AlexNet berhasil mengklasifikasikan 13 citra secara tepat dan mengalami kesalahan prediksi pada 7 citra. Nilai AUC sebesar 0,68 menempatkan AlexNet pada kategori *Poor Classification* berdasarkan skala evaluasi AUC. Hal ini disebabkan oleh keterbatasan kedalaman lapisan konvolusi AlexNet dalam mengekstrak fitur garis retakan tipis pada permukaan panel surya.
2. Arsitektur VGG16 mencatatkan performa yang jauh lebih unggul dengan akurasi sebesar 89,57% dan nilai AUC mencapai 0,90. VGG16 berhasil mengklasifikasikan 18 dari 20 citra uji dengan benar dan hanya salah pada 2 citra. Berdasarkan skala AUC, nilai 0,90 mengategorikan VGG16 ke dalam kualifikasi *Excellent Classification*.

Tabel 7. Hasil evaluasi per kelas

Arsitektur Model	Kelas Kerusakan	Precision (%)	Recall (%)	F1-Score (%)	Akurasi (%)	AUC Score	Kategori AUC
AlexNet	Crack	87,50%	87,50%	87,50%	88,93%	0,68	<i>Poor Classification</i>
	Scratch	90,00%	90,00%	90,00%			
VGG16	Crack	90,00%	90,00%	90,00%	89,57%	0,90	<i>Excellent Classification</i>
	Scratch	89,28%	89,28%	89,28%			

Keunggulan VGG16 terletak pada penggunaan arsitektur konvolusi bertumpuk dengan kernel berukuran kecil (3x3). Struktur ini memungkinkan jaringan mengekstrak fitur spasial citra kerusakan secara lebih halus, mendalam, dan kaya informasi dibandingkan struktur konvolusi AlexNet yang relatif lebih dangkal.

Meskipun perbandingan akurasi antara VGG16 (89,57%) dan AlexNet (88,93%) hanya menunjukkan selisih tipis sebesar 0,64%, klaim keunggulan arsitektur VGG16 tidak bertumpu pada metrik akurasi semata. Keunggulan signifikan VGG16 ditunjukkan secara kontras melalui nilai Area Under the ROC Curve (AUC), di mana VGG16 mencatatkan AUC sebesar 0,90 (kategori Excellent Classification), sedangkan AlexNet hanya memperoleh AUC sebesar 0,68 (kategori Poor Classification). Selisih nilai AUC yang lebar sebesar 0,22 (22%) ini membuktikan bahwa VGG16 memiliki kemampuan ambang batas pemisahan kelas (class separability power) dan tingkat sensitivitas yang jauh lebih superior dibandingkan AlexNet. Pada AlexNet, nilai AUC 0,68 mengindikasikan tingginya variansi probabilitas prediksi, di mana model sering berada pada batas keraguan dalam memisahkan fitur crack dan scratch meskipun hasil akhir prediksi kelasnya sering kali benar secara kebetulan.

Keunggulan VGG16 dalam membedakan pola kerusakan permukaan sel surya dapat dijelaskan melalui arsitektur jaringan dan kedalaman lapisan konvolusinya:

1. Dampak Kedalaman Lapisan (Layer Depth):

VGG16 memanfaatkan 13 convolutional layer bertumpuk dengan receptivity field yang konsisten kecil (3x3), berbeda dengan AlexNet yang hanya memiliki 5 convolutional layer dengan receptive field besar di layer awal (11x11 dan 5x5). Kedalaman lapisan pada VGG16 memungkinkan jaringan membangun representasi fitur secara hierarkis (hierarchical feature learning). Lapisan awal menangkap garis tepi sederhana (edges), lapisan menengah membentuk tekstur, dan lapisan mendalam (deeper layers) merangkai pola spasial kompleks dari retakan (crack) dan goresan (scratch).

2. Respons Fitur Terhadap Pola Crack vs Scratch:

Cacat retakan (crack) pada modul sel surya umumnya memiliki karakteristik garis halus meliuk dengan kontras intensitas lokal yang tipis terhadap latar belakang panel. Sebaliknya, goresan (scratch) cenderung memiliki pola garis lurus berulang dengan refleksi cahaya yang bervariasi. Filter 3x3 berulang pada VGG16 memberikan efek non-linearitas yang lebih tinggi (melalui multiple ReLU activations), sehingga mampu mempertahankan detail mikroskopis retakan tanpa terpengaruh oleh noise latar belakang. Sebaliknya, filter besar pada AlexNet cenderung melakukan smoothing (penghalusan) terhadap piksel, yang menyebabkan garis retakan tipis kehilangan detail spasialnya di lapisan-lapisan awal konvolusi.

Hasil penelitian ini memberikan implikasi penting bagi pengembangan sistem inspeksi otomatis panel surya di lapangan. Dengan nilai AUC sebesar 0,90 dan F1-Score mencapai 90%, arsitektur VGG16 terbukti sangat ideal untuk diintegrasikan ke dalam perangkat lunak drone atau kamera inspeksi genggam untuk mendeteksi retakan dini secara presisi. Sementara itu, meskipun AlexNet memiliki AUC lebih rendah (0,68), ukurannya yang sangat ringan dan waktu komputasi yang cepat dapat dijadikan pertimbangan untuk sistem pemindaian awal (pre-screening) berdaya rendah sebelum verifikasi mendalam dilakukan oleh model VGG16

4. KESIMPULAN

Penelitian ini telah berhasil mengimplementasikan dan membandingkan dua arsitektur *Deep Learning* (AlexNet dan VGG16) untuk mengklasifikasikan kerusakan permukaan pada modul panel surya (*crack* dan *scratch*). Berdasarkan hasil eksperimen dan evaluasi performa:

1. Arsitektur VGG16 terbukti lebih andal dan unggul dibandingkan AlexNet. VGG16 meraih akurasi sebesar 89,57% dengan nilai AUC 0,90 (*Excellent Classification*).
2. Arsitektur AlexNet memperoleh akurasi sebesar 88,93% dengan nilai AUC 0,68 (*Poor Classification*).

3. Penggunaan kombinasi optimizer *Adam* (learning rate 0.001) dan mekanisme *Early Stopping* terbukti efektif dalam mempercepat proses konvergensi serta mencegah terjadinya kondisi *overfitting* selama pelatihan model.

Untuk penelitian selanjutnya, disarankan untuk memperluas cakupan kelas kerusakan (seperti *hotspot* atau *dirt/spot*) serta mencoba menerapkan metode *Transfer Learning* atau arsitektur modern seperti ResNet dan EfficientNet untuk meningkatkan akurasi klasifikasi lebih lanjut. Penelitian ini memiliki keterbatasan pada ukuran dataset pengujian yang digunakan dalam evaluasi mandiri. Meskipun hasil eksperimen awal menunjukkan keunggulan VGG16 dengan AUC 0,90, validasi pada skala dataset yang jauh lebih besar dan bervariasi (termasuk variasi kondisi pencahayaan dan sudut pengambilan gambar) sangat direkomendasikan pada penelitian selanjutnya untuk lebih memperkuat generalisasi model di lapangan.

DAFTAR PUSTAKA

- [1] N. T. Hadi, M. P. Muslim, K. W. Gusti, and R. T. Prasetyo, "Pemberdayaan masyarakat berbasis energi surya untuk mendukung desa cerdas energi dan meningkatkan kesejahteraan," *Jurnal Inovasi Hasil Pengabdian Masyarakat (JIPEMAS)*, vol. 8, pp. 765–777, Nov. 2025, doi: 10.33474/jipemas.v8i3.24287.
- [2] F. Irawati, F. Dwi Kartikasari, and E. Tarigan, "Pengenal Energi Terbarukan dengan Fokus Energi Matahari kepada Siswa Sekolah Dasar dan Menengah," vol. 11, 2021, [Online]. Available: <http://ojs.unm.ac.id/index.php/>
- [3] M. Perarasi, J. Jasmine Hephzipah, M. Dinesh Babu, and K. Kamakshi Priya, "An efficient solar panel crack detection system using a novel solcnn model and crack segmentation algorithm," *Results in Engineering*, vol. 29, Mar. 2026, doi: 10.1016/j.rineng.2026.108995.
- [4] S. W. Lee, K. E. An, B. D. Jeon, K. Y. Cho, S. J. Lee, and D. Seo, "Detecting faulty solar panels based on thermal image processing," in *2018 IEEE International Conference on Consumer Electronics, ICCE 2018*, Institute of Electrical and Electronics Engineers Inc., Mar. 2018, pp. 1–2. doi: 10.1109/ICCE.2018.8326228.
- [5] Thomas Brian, Immanuel Freddy Augustino, P. Parman, and Muhamad Sukarno, "Damage Detection System for Floating Solar Panels at Sidobandung Pond Based On Convolutional Neural Networks with Augmented Reality Visualization," *TEKNIMEDIA: Teknologi Informasi dan Multimedia*, vol. 7, pp. 12–21, Jun. 2026, doi: 10.46764/teknimedia.v7i1.364.
- [6] S. Krig, *Computer Vision Metrics: Survey, Taxonomy, and Analysis of Computer Vision, Visual Neuroscience, and Visual AI, Second Edition*. Springer Nature, 2025. doi: 10.1007/978-981-99-3393-8.
- [7] R. Alfan and J. C. Imamul Muttaqin, "Perancangan Deteksi Cacat Pada Layer Solar Cell Menggunakan Sensor Tegangan Static Permukaan Berbasis Bluetooth".
- [8] CodedThemes and F. D. Lestary, "IMPLEMENTASI DEEP LEARNING UNTUK PENDETEKSIAN SNAIL TRAILS PADA MODUL SEL SURYA = Deep Learning Implementation for Snail Trails Detection in Photovoltaic Module," 2023.
- [9] CodedThemes and A. N. N. A. Ibrahim, "Pendekatan Identifikasi Hot Spot untuk Aplikasi Inspeksi Panel Surya menggunakan Pencitraan Termal = An Approach for Hot Spot Identification in Solar Panel Inspection Application Using Thermal Imaging," 2024.
- [10] "Optimasi Algoritma Convolutional Neural Network dengan Arsitektur Efficientnet-B0 dan Resnet-50 untuk Klasifikasi Jenis Sampah," 2026, doi: 10.57152/malcom.v5i4.2030.
- [11] M. G. Han, "Pengaruh Penambahan Arsitektur Model dalam Klasifikasi Citra Bencana Alam Menggunakan Ensemble Learning," 2026, doi: doi.
- [12] E. Tanuwijaya and A. Roseanne, "Modifikasi Arsitektur VGG16 untuk Klasifikasi Citra Digital Rempah-Rempah Indonesia," *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 21, pp. 189–196, Nov. 2021, doi: 10.30812/matrik.v21i1.1492.
- [13] R. García-Aguirre, E. M. Navarro-López, and L. Torres-Treviño, "Gen-CNN: a framework for the automatic generation of CNNs for image classification," *Neural Comput. Appl.*, vol. 37, no. 1, pp. 149–168, 2025.
- [14] J. Zhao, Y. Wu, R. Deng, S. Xu, J. Gao, and A. Burke, "A Survey of Autonomous Driving from a Deep Learning Perspective," *ACM Comput. Surv.*, vol. 57, May 2025, doi: 10.1145/3729420.
- [15] M. Perarasi, J. Jasmine Hephzipah, M. Dinesh Babu, and K. Kamakshi Priya, "An efficient solar panel crack detection system using a novel solcnn model and crack segmentation algorithm," *Results in Engineering*, vol. 29, Mar. 2026, doi: 10.1016/j.rineng.2026.108995.
- [16] R. Saha, "CRISP-DM-guided hyperparameter-optimized ensemble model for mental health diagnosis," *Network Modeling Analysis in Health Informatics and Bioinformatics*, vol. 15, Dec. 2026, doi: 10.1007/s13721-025-00705-z.

- [17] J. L. Selder *et al.*, “Cardiology hospital admission risk prediction: training, internal validation and technical implementation in the electronic health record.,” *European heart journal. Digital health*, vol. 7, p. ztag109, Aug. 2026, doi: 10.1093/ehjdh/ztag109.
- [18] A. M. Wahid, T. Hariguna, and G. Karyono, “Optimizing Feature Extraction for Website Visuals: A Comparative Study of AlexNet and Inception V3,” in *2024 12th International Conference on Cyber and IT Service Management (CITSM)*, IEEE, 2024, pp. 1–6.
- [19] F. C. Chen and M. R. Jahanshahi, “ARF-Crack: rotation invariant deep fully convolutional network for pixel-level crack detection,” *Mach. Vis. Appl.*, vol. 31, no. 6, Sep. 2020, doi: 10.1007/S00138-020-01098-X.
- [20] N. Wiliani, T. Khawa, and S. Ramli, “Extraction of Solar Panel Image Texture Feature Using GLCM Method for Damage Analysis on Solar Panel Surface Images,” in *E3S Web of Conferences*, EDP Sciences, Apr. 2025. doi: 10.1051/e3sconf/202562201001.
- [21] K. Maharana, S. Mondal, and B. Nemade, “A review: Data pre-processing and data augmentation techniques,” *Global Transitions Proceedings*, vol. 3, pp. 91–99, Jun. 2022, doi: 10.1016/j.gltp.2022.04.020.
- [22] Ricky Putra Sardika and W. Widhiarso, “Klasifikasi Otomatis Tingkat Kerusakan Retak Bangunan pada Citra Digital Menggunakan MobileNetV2 dan Augmentasi Data,” *Arcitech: Journal of Computer Science and Artificial Intelligence*, vol. 5, pp. 108–124, Jun. 2025, doi: 10.29240/arcitech.v5i1.13938.
- [23] Baiq Nurul Azmi, Arief Hermawan, and Donny Avianto, “Analisis Pengaruh Komposisi Data Training dan Data Testing pada Penggunaan PCA dan Algoritma Decision Tree untuk Klasifikasi Penderita Penyakit Liver,” *JTIM : Jurnal Teknologi Informasi dan Multimedia*, vol. 4, pp. 281–290, Feb. 2023, doi: 10.35746/jtim.v4i4.298.
- [24] S. Mascarenhas and M. Agarwal, “A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification,” in *2021 International conference on disruptive technologies for multi-disciplinary research and applications (CENTCON)*, IEEE, 2021, pp. 96–99.
- [25] “Softmax Regression: Kunci Klasifikasi Multi-Kelas dalam Artificial Intelligence untuk Bisnis Indonesia,” <https://arsa.technology/machine-state/softmax-regression-kunci-klasifikasi-multi-kelas-d-0j69v4ur/>.
- [26] S. Walters, “Area Under the Curve (AUC),” in *Encyclopedia of Quality of Life and Well-Being Research*, Springer, 2024, pp. 252–254.